

EL ENSEMBLE DE CORTO PLAZO LAM-EPS AEMET- γ SREPS

David QUINTERO PLAZA¹, Alfons CALLADO PALLARÈS², Pau Aitor ESCRIBÀ AYERBE³,
Mauri MARTÍNEZ SÁNCHEZ⁴, David GIL OLIVA⁵

¹Delegación Territorial de AEMET en Canarias,

^{2,3,4,5}Delegación Territorial de AEMET en Cataluña

dquinterop@aemet.es, acalladop@aemet.es, pescribaa@aemet.es,

mmartinezs@aemet.es, dgilo@aemet.es

RESUMEN: En este artículo se van a exponer brevemente las principales características del ensemble de corto plazo LAM-EPS AEMET- γ SREPS, más conocido simplemente como el γ SREPS, activo desde abril de 2016 y en situación preoperativa en el Sistema Nacional de Predicción de AEMET al escribir estas líneas. El γ SREPS es un sistema de predicción meteorológica por conjuntos, es decir, una agrupación de múltiples simulaciones de predicción, todas ellas igualmente plausibles, que corre en el corto plazo (en los siguientes dos o tres días contando desde el día actual). Los productos para la predicción operativa son de carácter probabilístico, lo que puede resultar un tanto chocante al principio, por la tendencia innata de pensar en términos de deterministas y por las sutilezas que conlleva el manejo de la probabilidad y la estadística; sin embargo, es importante resaltar que hay un acuerdo unánime científico-técnico entre los expertos en que la predicción de más calidad, la más informativa y la más completa es intrínsecamente probabilista.

El γ SREPS es un sistema de predicción meteorológica innovador y único a nivel mundial. Utiliza cuatro modelos distintos de área limitada (de los más avanzados para alta resolución) que combina con la información de cinco de los modelos globales más importantes de la actualidad. Todo ello da lugar a veinte miembros que generan veinte predicciones para dos áreas, la Península más Baleares y Canarias. Durante la campaña antártica, el γ SREPS también ofrece predicciones a la base española sita en Livingston. Las veinte predicciones pueden combinarse de múltiples formas para generar toda una serie de productos probabilistas, los cuales son extremadamente informativos y resultan de gran ayuda en la predicción operativa.

Con este sistema, AEMET se coloca en una posición destacada a nivel mundial en la predicción por conjuntos aplicada al corto plazo.

Palabras clave: predicción por conjuntos, *ensemble*, predicción probabilística, alta resolución.

1. LA NECESIDAD DE UNA PREDICCIÓN DE TIPO PROBABILISTA

Desde hace tiempo se viene haciendo uso de términos de probabilidad para las predicciones de corto plazo (hasta el D+2, donde D indica el día actual). En los boletines, los predictores emplean expresiones como “probable” o “no se descarta”, y en predicciones más específicas, como las de los aeropuertos, se dan probabilidades numéricas. Sin embargo, clásicamente la cuantificación de esta probabilidad no se hacía por medios objetivos tales como el resultado de un modelo probabilista (ya que para el corto plazo los modelos eran solo deterministas), sino mediante el conocimiento de la situación meteorológica del predictor, su experiencia y/o el uso combinado de varios modelos (*poor man ensemble*). Los modelos probabilistas consumen muchos más recursos computacionales que los

deterministas y a finales del pasado siglo no estaban disponibles para el corto plazo; sí están accesibles desde hace poco más de una década para el medio plazo, es decir, a partir del D+2.

Los modelos deterministas, que ofrecen una salida única para un conjunto de datos de entrada, funcionan cada vez mejor, y además poco a poco aumentan más la resolución (la escala de los fenómenos que pueden discernir) con lo que son herramientas muy poderosas. Sería posible preguntarse por qué razón son necesarios los modelos probabilistas. Hay al menos cuatro argumentos en favor de una predicción de tipo probabilista:

1.1. El argumento intelectual

En el proceso de predicción se hacen muchas aproximaciones: no se conoce el estado de la atmósfera con precisión, nuestras observaciones no son perfectas, muchos procesos físicos son simplificados a la hora de introducirlos en las ecuaciones de los modelos y las propias ecuaciones son resueltas por métodos numéricos aproximados, dado que no tienen una solución analítica. Con toda esa acumulación de pequeños errores, incertidumbres y aproximaciones, parece lo más honesto, desde una postura puramente intelectual, el que un modelo de predicción ofrezca no solo un resultado concreto sino también una medida de la dispersión alrededor de ese valor, una medida de su incertidumbre, o dicho de otra manera, una medida de su predecibilidad.

1.2. El argumento económico

Es posible enfocar la reacción de un usuario cualquiera ante una predicción en función de sus costes (C), asociados a dejar de hacer lo que tenía pensado cuando se entera de una predicción que le es adversa; y sus pérdidas (L), cuando decide no modificar su actuación y se cumple la predicción adversa. Estas cantidades se estudian como un cociente C/L (coste/pérdida). La clave es la siguiente: un usuario siempre debe modificar su actuación cuando el cociente C/L es menor que la probabilidad del fenómeno, lo que indicaría que sus pérdidas serían muy cuantiosas.

Se puede ver todo más claro con un ejemplo. Suponga (PALMER y HAGEDORN, 2001) el caso de un constructor que tiene que verter cemento en una obra. Le interesaría saber si va a llover o no al día siguiente. Si no vierte el cemento retrasará un día más la obra y el coste es de 1600 euros; y por otro lado, si vierte el cemento y llueve, pierde varios días de trabajo teniendo que limpiar y arreglar el desaguisado, se puede suponer una pérdida de 4000 euros. El cociente C/L es de 0,4. Ahora imagine que la predicción del predictor, que se ha leído este artículo y está convencido de usar modelos probabilistas, es de lluvia con un 80 % de probabilidad (0,8 en una escala de 0 a 1). Dado que C/L, 0,4, es menor que 0,8, el constructor “no” debe verter el cemento. La lluvia es demasiado segura para compensar las pérdidas frente al coste. Si, en cambio, la probabilidad de lluvia fuera de 0,1 (10 %), siendo 0,4 mayor que 0,1, la “actuación más racional” sería verter el cemento; si llueve, perdería 4000 euros, pero como eso solo sucederá una vez de cada diez, le compensa asumir el riesgo para no perder los casi seguros 1600 euros de no actuar. El constructor puede perder dinero una vez siguiendo este sistema, pero si debe verter cemento en dichas condiciones muchas veces, y actúa repetidamente de esta manera a lo largo del tiempo, le sale muy a cuenta. Con un modelo determinista, que ofrece una predicción binaria (lluvia sí/lluvia no), el constructor nunca tendría margen para tomar una decisión, y a la larga, sus pérdidas serían mayores (es posible demostrar esto de forma rigurosa matemáticamente).

Se pueden poner pegos a este argumento: no todos los costes ni todas las pérdidas son fáciles de calcular; ni siquiera todo es cuantificable en términos C/L. Incluso, ni siquiera queda claro que las personas, aun conociendo este argumento, actuaran siempre de forma racional. Existe la llamada “aversión al riesgo”, fenómeno conocido dentro la interrelación de la psicología y la economía; en este caso, la aversión al riesgo podría ser que el constructor nunca quisiera verter cemento a menos que la predicción diese un 0 % de lluvia.

Aun con todas estas críticas, el argumento económico es potente, y la predicción probabilista ofrece mucha información a los muy diversos usuarios (con distintos C/L) para que optimicen su actuación.

1.3. El argumento de la cantidad de información

En el apartado anterior ha hecho su aparición el término “información”. La predicción probabilista se realiza con varios modelos o con el mismo modelo perturbado para simular situaciones diferentes. Por lógica, la combinación de modelos tiene que ofrecer más información que la salida de un único modelo. Y de hecho, es así. Puede incluso justificarse matemáticamente usando la definición de cantidad de información o entropía de Claude Shannon (S es la entropía, p la probabilidad):

$$S = -\sum_i p_i \log p_i$$

Cuando la predicción es determinista, la información, S, es cero (cuando $p = 1$, $S = 0$, y cuando $p = 0$ hay una indeterminación 0 por menos infinito, pero el término lineal domina al logaritmo y el resultado es cero). Con cualquier término probabilístico distinto a 0 o 1, $S > 0$.

Incluso cuando una predicción falla, la predicción probabilista ofrece más información, ya que no se limita a dar un valor concreto, sino un conjunto de escenarios posibles; es de suponer que, salvo inconsistencia en el *ensemble*, el valor observado esté cerca de uno de esos escenarios, aunque sea con baja probabilidad. Por supuesto, esto no significa que haya que usar la predicción probabilista para “acertar más”, dado que esta predicción tiene verificaciones y controles de calidad que penalizan más cuando sucede un escenario menos probable que uno más probable. No obstante, incluso en el caso de fallar, el usuario siempre recibirá más información. Usualmente, eventos significativos severos y/o extremos tienen baja probabilidad en un *ensemble*, y solo son simulados por dos o tres miembros; aunque la información sea poca, esto pone sobre aviso al predictor para vigilar que la atmósfera real no evolucione hacia esos escenarios/miembros.

1.4. El argumento científico

Este argumento está muy relacionado con el argumento intelectual. Es un hecho conocido desde los años 60 del pasado siglo que la atmósfera es un sistema caótico. El caos es típico de sistemas no lineales (y las ecuaciones de la atmósfera lo son, y mucho), que tienen una gran sensibilidad a las condiciones iniciales. Una mínima variación en las condiciones iniciales, en el estado inicial de la atmósfera, puede amplificarse enormemente y, el resultado tras varios días, diferir mucho del resultado producido por unas condiciones iniciales casi idénticas.

Esto hace que, por mucho que mejoren los modelos deterministas, nunca se tiene la predicción perfecta, dado que estos modelos siempre serán alimentados con datos que

tienen incertidumbres, ya que es imposible conocer con toda precisión el estado de toda la atmósfera en un momento dado; como se ha dicho, estas mínimas diferencias pueden amplificarse mucho con el paso del tiempo. Un sistema de predicción probabilista como un *ensemble* cuantificará (también de forma aproximada y discreta) esta dispersión de escenarios y será por tanto más cercano a la “realidad”. Se verá un ejemplo muy claro de esto en la sección 3. Es importante resaltar que, con mejores y más observaciones, y con mejores modelos, y a pesar de que siempre haya cierta incertidumbre inherente, los sistemas de predicción probabilista mejorarán acotando mejor la incertidumbre y alargando temporalmente el límite de la predecibilidad.

2. EL ENSEMBLE DE CORTO PLAZO γ SREPS

2.1. Una breve introducción a los *ensembles*

El *ensemble* o agrupación de modelos más famoso del mundo es probablemente el del Centro Europeo de predicción, el ECMWF. Es un *ensemble* de medio plazo (aunque podría usarse para el corto plazo también; no obstante, al no estar optimizado para el corto plazo, esto no es aconsejable). La resolución actual (2019), acoplada a la evolución oceánica, es de unos 18 kilómetros en la horizontal y 91 niveles verticales (la resolución horizontal baja un poco más a partir del D+15). Su poderoso sistema de asimilación de datos, esto es, el modo en que el modelo absorbe los datos de las observaciones, evalúa su calidad y los ingesta para hacer las predicciones, unido a las características anteriores, ha convertido al




Figura 1. Ejemplo de plumas de los diversos miembros del modelo del Centro Europeo. En rojo discontinuo, el modelo de alta resolución; en continuo, el miembro de control; en rojo discontinuo suave, el resto de miembros del ensemble; en verde, las probabilidades.

(ECMWF User Guide: <https://confluence.ecmwf.int/display/FUG/Plumes>).




Figura 2. Ejemplo de box plot. Los valores son, de arriba hacia abajo: el máximo, el percentil 90, el 75, 50, 24, 10 y el valor mínimo. La dispersión, en general, aumenta con el alcance de la predicción mientras la predecibilidad disminuye. (ECMWF User Guide: <https://confluence.ecmwf.int/display/FUG/Meteograms>).

modelo del Centro Europeo en el mejor modelo global (de todo el planeta) del mundo, al menos hoy por hoy.

Para crear su famoso *ensemble* de medio plazo con 51 escenarios, el modelo determinista es perturbado generando 50 escenarios. El escenario adicional se llama “control”, porque usa el modelo determinista sin perturbación de ningún tipo (aunque con una resolución algo menor). Los otros 50 modelos son el resultado de perturbaciones en las condiciones iniciales más perturbaciones internas para tener en cuenta sus incertidumbres inherentes (en 2019 con la parametrización estocástica SPPT). Existen muchas técnicas para perturbar modelos y el Centro Europeo las ha ido evolucionando a lo largo de su historia. Estas perturbaciones, desarrolladas, dan lugar a 50 escenarios. Como 50 escenarios son muchos, a veces se agrupan los escenarios por su similitud. A cada escenario se le llama “miembro” y a cada agrupación “grupo”. Cuando la mayoría de miembros se parecen, hay alta predecibilidad, cuando las diferencias son notorias se habla de baja predecibilidad. Existen muchas formas de dar una idea de la dispersión de la predicción, y el Centro Europeo utiliza bastantes sistemas, como las “plumas” o los *box plot* (véanse las figuras 1 y 2).

2.2. Las condiciones de contorno del γ SREPS

Como se explicó en el resumen del artículo, el γ SREPS tiene 20 miembros. Al ser un *ensemble* de modelos de alta resolución, trabaja a nivel local, es decir, no resuelve todo el

globo terráqueo, sino tan solo las zonas que se le especifiquen. Estas zonas son, actualmente, la península ibérica, Canarias y un área alrededor de las bases españolas de la Antártida (llamada dominio Livingston). Como cualquier modelo de alta resolución regional, el γ SREPS es alimentado por modelos globales, modelos que sí que resuelven el planeta entero, proporcionando las “condiciones de contorno”, que son también las condiciones iniciales. El γ SREPS utiliza 5 modelos globales: el IFS del Centro Europeo, el GEM canadiense, el GFS de la NOAA (norteamericano), el ARPÈGE de Météo-France y el GSM japonés. El objetivo de usar condiciones de contorno de diferentes modelos es análogo al de usar distintos modelos de alta resolución que se comenta más adelante: representar las incertidumbres que tiene la atmósfera.

Cada uno de estos modelos utiliza sus propios criterios a la hora de organizar la información, de proveerla y de tratarla. Por ejemplo, los modelos no usan los mismos puntos tanto verticales como horizontales en los que discretizan las variables a calcular (un modelo no calcula sino en determinados puntos, cuanto más cercanos estos, más resolución). Por tanto, para poder ingestar, adecuadamente y con un criterio unificado, los datos de todos estos modelos en el γ SREPS, hacen falta interpolaciones en la horizontal y en la vertical, hay que cambiar unidades y recalcular algunos campos. Esto es un esfuerzo considerable y hace estar siempre vigilantes por si algún modelo de los globales cambiase en algún momento los parámetros de sus salidas. Por otro lado, no hay que olvidar el gran trabajo a nivel diplomático e internacional para conseguir las mejores condiciones de contorno posibles de cinco agencias meteorológicas distintas. Este trabajo, al igual que el trabajo técnico, en cierto modo nunca termina.

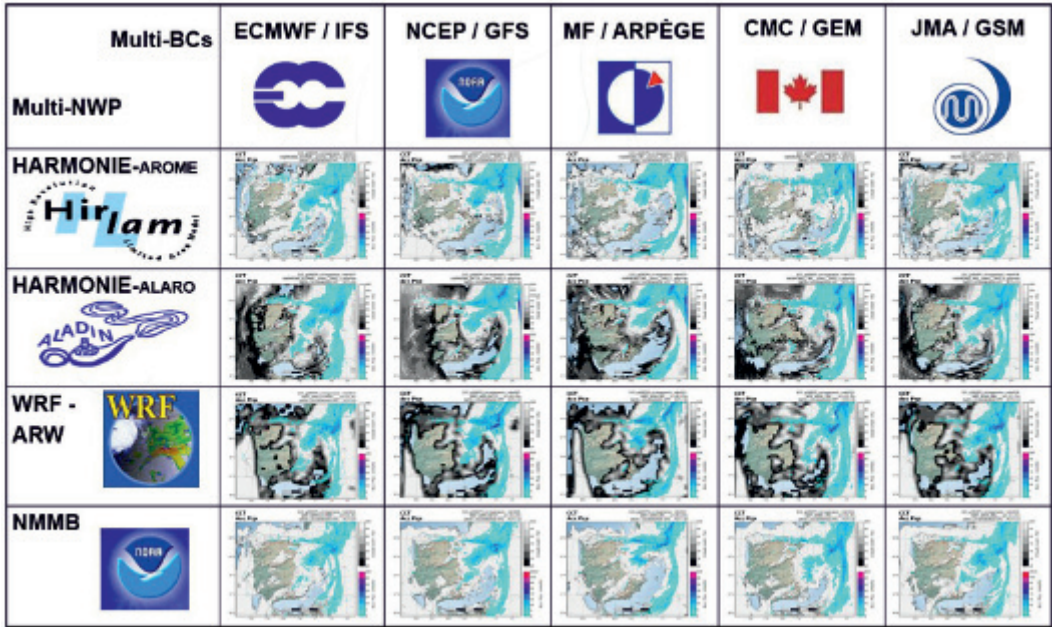


Figura 3. El γ SREPS, presentación general. Los modelos globales para las condiciones de contorno están en la horizontal superior y los modelos locales de alta resolución que resuelven las ecuaciones, en la vertical.

2.3. El concepto “multimodelo” del γ SREPS

El concepto de “multimodelo” surge a finales de los años noventa, con un original trabajo de Eugenia Kalnay y Dingchen Hou (KALNAY y HOU, 2001) que sugiere que la aproximación ideal a los *ensembles* sería utilizar varios modelos para representar las condiciones de contorno en lugar de uno solo al que se perturba. La idea es que esto representaría las incertidumbres inherentes en la atmósfera de forma tan adecuada o más que un *ensemble* de un único modelo que es perturbado. Esta técnica se ha ido extendiendo poco a poco (PALMER y otros, 2004), aunque a nivel operativo y para el corto plazo, AEMET es la única agencia del mundo que la llevó a la práctica desde 2006 a 2014 con el SREPS “clásico” (GARCÍA-MOYA y otros, 2011), y actualmente con el γ SREPS, con tantos modelos diferentes (5 para las condiciones de contorno y 4 de alta resolución para resolver las ecuaciones).

Los modelos de alta resolución son: dos versiones de Harmonie (ALARO y AROME), que difieren totalmente en la física y en algunos aspectos de la dinámica (en modelización se llama física a todo lo que no es la dinámica); el NMMB, un modelo operativo para la predicción usado en los Estados Unidos por el NCEP (NOAA); y el WRF-ARW, quizá el modelo más popular del mundo debido al hecho de que es código abierto, enfocado a la investigación. La inclusión del WRF-ARW es interesante porque es un modelo que se suele usar mucho en el campo experimental más que en la operatividad; de hecho, es con diferencia el modelo menos optimizado, y por tanto, el más lento computacionalmente de todos los del γ SREPS; sin embargo, como comenta Alfons Callado, el WRF-ARW es un modelo menos conservador que tiende a arriesgar más que el resto, lo que puede dar falsas alarmas a veces, pero también puede ser el único que capte determinadas situaciones atmosféricas extremas y/o severas de baja predecibilidad. Por tanto, si bien tener el WRF-ARW como modelo operativo podría ser una decisión un tanto arriesgada, en un *ensemble* sí que puede aportar considerable valor. Ofrece un “punto de vista diferente”, por así decirlo.

La inclusión de varios modelos numéricos de alta resolución da cuenta de los posibles errores e incertidumbres de los modelos a la hora de predecir el comportamiento futuro de la atmósfera. Más concretamente, se dice que el “multimodelo” da idea de las incertidumbres en la mesoescala (escala entre autonómica y provincial), de forma análoga a como las diversas condiciones de contorno dan cuenta de las incertidumbres iniciales y del contorno del dominio de integración de los modelos (en este último caso a una escala más grande, técnicamente referida como sinóptica, la escala de la península ibérica).

2.4. Descripción con más detalle de los diferentes modelos y de la configuración del γ SREPS

Dado que el γ SREPS consta de 4 modelos, ha habido que preparar las configuraciones de estos modelos para que sean lo más parecidas entre sí para tener consistencia en el *ensemble*. En general, se han seguido los criterios que marcaban los Harmonies, por ser los modelos más conocidos en AEMET.

La resolución horizontal es de 2,5 kilómetros para todos. La proyección usada es cónica conforme de Lambert; esta proyección es común en modelos de alta resolución, sin embargo, no es la original interna del NMMB (que usa una “*latlon* rotada”), aunque está preparado para dar su salida en una Lambert. La idea es que los modelos usen los mismos puntos de *grid* o puntos lo más próximos posibles para que sean lo más consistentes posibles. Los Harmonies y el WRF-ARW usan una Lambert con 565 puntos en la longitud y

469 de latitud para las tres áreas (Península, Canarias y Antártida). En la figura 4 se puede ver de forma aproximada la coincidencia de los puntos. No todos tienen el mismo número de puntos en la horizontal: al modelo NMMB hubo que añadirle unos puntos extra porque al rotarlo cierta información de los bordes se perdía.




Figura 4. El grid horizontal del γ SREPS. La coincidencia de los puntos es total para los Harmonies y WRF-ARW, y muy aproximada para el NMMB. (Nota: se representan solo uno de cada 15 puntos de grid o rejilla originales).

En cuanto a la vertical, se tienen los Harmonies ALARO y AROME con 65 niveles en la vertical y los WRF-ARW y NMMB con 72. Estos niveles son casi coincidentes en las capas bajas de la atmósfera, en lo que se llama la PBL (*Planetary Boundary Layer*) o capa límite planetaria; el lugar donde ocurren los fenómenos meteorológicos más relevantes. En niveles medios difieren muy poco, y en los más altos la coincidencia es menos exacta, pero aun así similar. Si la orografía es compleja la diferencia se puede apreciar un poco más, aunque siguen siendo muy similares.

La consistencia entre modelos va mucho más allá de la coherencia entre las resoluciones horizontales y verticales. Por ejemplo, se ha tenido especial cuidado en que la entrada de energía en los modelos, la radiación solar, se actualice cada 15 minutos en las simulaciones para todos ellos. También se ha vigilado que la transición entre los distintos modelos globales y los modelos regionales sea suficientemente espaciosa, y por consistencia, igual entre todos ellos.

Por último, es interesante comentar como son los diversos procesos del γ SREPS en una ejecución operativa. El γ SREPS es una intrincada red de procesos dependientes muchos de




Figura 5. El grid vertical del γ SREPS. La coincidencia de los niveles bajos sobre el mar de los Harmonies (AROME y ALARO) respecto al WRF y al NMMB es casi total. En orografías complejas difieren más por tener definiciones diferentes de niveles verticales.

ellos de otros, organizados formando una estructura de árbol. Hay tres dominios (Península, Canarias y Livingston) y cuatro grandes bloques de ejecución manejados por el gestor de tareas del ECMWF, el *ecflow*. Dentro de los grandes bloques de ejecución se tienen los procesos:

- 1_bcs, que hace referencia a la gestión de las condiciones de contorno;
- 2_eps, que hace referencia al EPS propiamente dicho;
- 3_grb, que hace referencia a la generación de productos en formato GRIB; y
- 4_vrf, que es la generación automática de una verificación objetiva.

Con la herramienta visual e interactiva *ecflow_ui* del Centro Europeo se facilita mucho la gestión del γ SREPS.

3. PRODUCTOS DEL γ SREPS. PRIMERAS VERIFICACIONES

3.1. Productos del γ SREPS

En la web del γ SREPS es posible seleccionar el dominio en el que se quiere trabajar (Livingston, Península o Canarias). Una vez allí se puede elegir entre las subáreas u optar por una visión panorámica. En la web hay todo un conjunto de productos disponibles para los predictores. Son productos probabilistas, aunque hay un producto que muestra salidas de cada uno de los 20 miembros del γ SREPS.

En la web, antes de seleccionar ningún producto, lo que se puede ver es la mediana de la orografía de los miembros del γ SREPS. Cada modelo tiene su propia orografía, así que el resultado final es un agregado, aunque las diferencias son muy pequeñas entre los modelos salvo en puntos concretos muy montañosos. Ha de recordarse que la mediana es un estimador robusto y resistente en el sentido estadístico de estos dos términos. En esencia, la media se ve mucho más afectada por valores extremos que la mediana. El γ SREPS usa tanto la media como la mediana o incluso ambos según los casos: por ejemplo, se usa la media para la precipitación acumulada porque se piensa que así se reflejan mejor valores muy altos que diera algún miembro y que la mediana suavizaría, aunque por ser más robusta también se incluye. En cambio, se prefiere la mediana para la orografía como una medida más realista de lo que es el relieve que ve el *ensemble*.

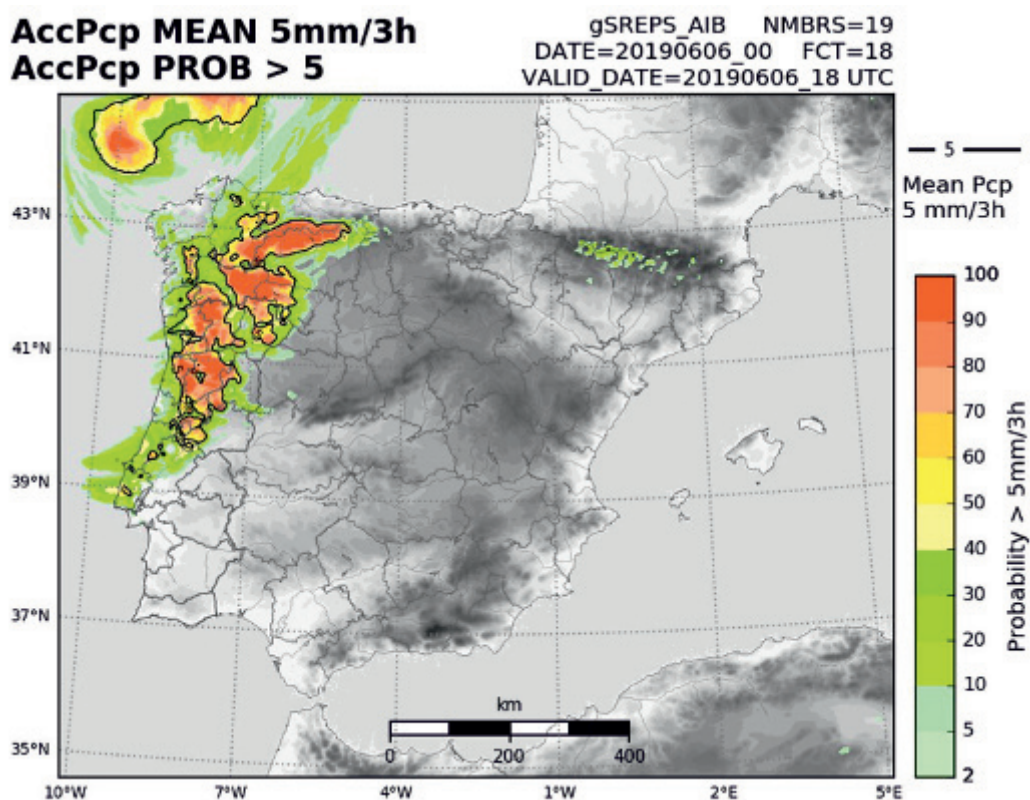


Figura 6. Ejemplo de salida probabilística del γ SREPS para la precipitación acumulada en 3 horas por encima de 5 mm.

En la web se trabaja mucho con la probabilidad de superar umbrales de valores de magnitudes meteorológicas. Estos umbrales hacen referencia a cantidades significativas para la predicción, tanto general como por ejemplo para los umbrales de aviso. La idea es que el γ SREPS sea una herramienta de apoyo fundamental para los eventos significativos y/o severos y/o extremos, y por ende, de los avisos que los predictores elaboran en el corto plazo. También se espera que sea una herramienta clave para fenómenos severos y/o extremos de baja predecibilidad, que pueden aparecer como escenarios en unos pocos miembros (como uno o dos), y que quizá no son suficientemente probables para emitir aviso, pero sí para poner en alerta a los predictores en tareas de vigilancia meteorológica, mostrándoles qué podrían esperar si la atmósfera real evolucionase hacia esos escenarios.

3.2. Primeras verificaciones del γ SREPS

El γ SREPS lleva en ejecución más de tres años en el momento de escribir este artículo (comenzó en marzo de 2016) y es un heredero del SREPS *clásico* (2005-2014) (SANTOS y otros, 2018). Desde su inicio, las verificaciones que se han llevado a cabo han sido y son muy prometedoras. La verificación de modelos es un campo muy extenso y específico para los *ensembles*, pero aquí se muestran al menos un par de gráficas para dar una idea de cómo verifica el γ SREPS frente a otros *ensembles*.

En la figura 7 es posible ver el valor del CRPS, un *score* que es la generalización del error absoluto medio (MSE) para el caso de predicciones probabilísticas. Cuanto más bajo es el CRPS, mejor es la predicción. En la gráfica se compara γ SREPS de 20 miembros (naranja) y de 12 miembros (amarillo) frente al *ensemble* de AROME-EPS de MétéoFrance (azul) de 12 miembros gracias a la colaboración en EPS hispano-francesa. En las primeras horas de la predicción, γ SREPS, de forma sorprendente, solo es ligeramente peor a veces. Esto no es nada grave, es de hecho esperable (en realidad, se esperaba una diferencia mayor) dado que el *ensemble* de AROME-EPS hace asimilación de datos de observaciones (una serie de algoritmos para inicializar adecuadamente modelos) mientras que en




Figura 7. Valor del CRPS para el *ensemble* de AROME, el γ SREPS con 20 miembros y el γ SREPS con 12 miembros. Cuanto más bajo, mejor. Las primeras horas de predicción van peor porque la asimilación aún no está configurada.

γ SREPS la asimilación no está disponible todavía. Tampoco es un gran problema, dado que los predictores pueden evitar los modelos en las primeras horas. Como se ve en la figura, una vez pasadas esas primeras horas, en mayo el γ SREPS superó a su homólogo francés, el AROME-EPS, ¡tanto con 12 como con 20 miembros! En el periodo de octubre mostrado, el rendimiento de AROME-EPS y γ SREPS con 20 miembros fue similar, quedándose algo más rezagado el γ SREPS de 12 miembros. En cualquier caso, un muy buen resultado del γ SREPS de 20 miembros, que será aún mejor cuando se disponga de asimilación de datos.

Se podrían mostrar más *scores* de verificación objetiva, pero quizá sea más interesante enseñar tres ejemplos de verificación subjetiva que muestran la fuerza y el interés del “multimodelo” y de las múltiples condiciones de contorno para un *ensemble*.

El caso de estudio que se ve en la figura 8 corresponde a una situación de una tormenta que se desarrolló de madrugada en el Maresme, zona litoral al norte de Barcelona. Esta situación convectiva tenía muy baja predecibilidad y de hecho no fue siquiera captada por los miembros que usan las condiciones de contorno del modelo del Centro Europeo en el γ SREPS. Sin embargo, un par de miembros sí vieron el desarrollo de la tormenta, y esto quedó reflejado en las probabilidades y en el campo de precipitación máxima que ofrecía el γ SREPS (aunque solo uno de los miembros de los 20 dio los 40 litros en el lugar correcto). El enfoque “multimodelo” y de múltiples condiciones de contorno condujo, eventualmente, a que ciertos miembros exploraran una región del espacio de fases que otros no exploraron; esta región del espacio de fases fue la que se desarrolló finalmente.

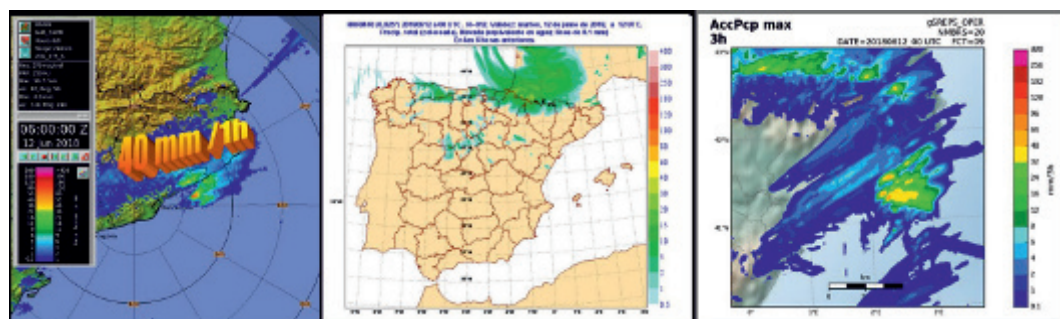


Figura 8. Lluvias intensas en el Maresme que llegaron a dejar 40 mm en menos de 1 hora, mostradas como imagen de radar (columna izquierda). Comparación de la salida del HARMONIE 40h1 con la precipitación máxima del γ SREPS (columna derecha).

En la figura 9 se tienen otros dos casos de estudio, uno de precipitación estratiforme (primera fila) y otro convectivo (segunda fila). Otra vez el mismo producto del γ SREPS (columna izquierda) se parece mucho más al campo de lluvia observado (columna central) que un EPS con HARMONIE y asimilación. Subjetivamente, parece ser el γ SREPS un muy buen *ensemble* para precipitaciones comparado con otros *ensembles* de la misma naturaleza.

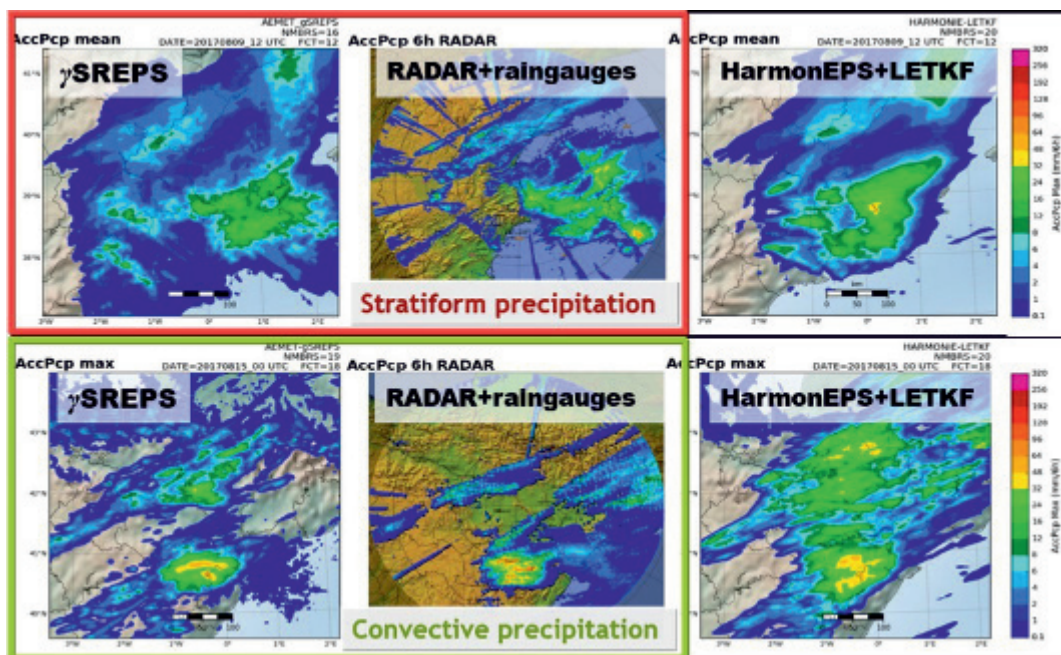


Figura 9. Dos nuevos ejemplos de lluvias intensas, de tipo estratiforme (fila superior) y convectiva (fila inferior). Comparación de la imagen del radar corregida con pluviómetros (columna central) con las precipitaciones máximas y medias del γ SREPS (columna izquierda) y del ensemble Harmonie AROME con asimilación (LETKF) (columna derecha), todas ellas para un acumulado en 6 horas.

4. FUTUROS DESARROLLOS

El γ SREPS está aún en desarrollo científico y técnico (como todos los *ensembles* homólogos), para pulir y mejorar muchos de sus aspectos, a pesar de que ya mismo es uno de los *ensembles* más potentes a nivel mundial como opción para la predicción en el corto plazo.

El siguiente gran paso será introducir en el γ SREPS la asimilación de los datos de observaciones y ejecuciones previas del modelo para su inicialización. De momento, se opta por la técnica LETKF, basada en filtros de Kalman, una forma de estimar variables no observadas de un sistema. (Lo que tiene bastante lógica, dado que en el momento inicial uno no tiene tampoco toda la información necesaria). Se espera, y ciertos resultados así parecen indicarlo, que el LETKF supere a 3D Var, un algoritmo de asimilación muy popular.

Por otro lado, en el futuro se quiere hacer calibración estadística del γ SREPS, con algún método estadístico convencional o quizá con *machine learning*. Debido a la demanda computacional, es posible que se empiece por calibrar tan solo en ciertos puntos especiales (como los aeropuertos) y quizá se pueda extender esta calibración a más puntos más adelante.

Y, por último, actualmente se valoran otras posibilidades de desarrollo futuro del γ SREPS como: aumentar a 25 miembros con el modelo GEM-LAM de alta resolución de los canadienses, aumentar el dominio sobre la península ibérica aprovechando el horizonte de más

disponibilidad de capacidad de cálculo de los superordenadores, integrar el sistema hasta tres días (D+3, 72 horas), etc... Habría que valorar todos estos puntos, dado que un *ensemble* es un sistema muy complejo en su desarrollo y que además consume muchísimos recursos computacionales, pero sería algo que daría aún más fuerza al γ SREPS.

Por supuesto, todo lo anterior no es óbice para futuros desarrollos no mencionados explícitamente y que puedan surgir sobre la marcha, bien para resolver problemas que vayan apareciendo o como nuevas ideas con vistas a la mejora.

5. CONCLUSIONES

Como se ha intentado mostrar en este artículo, la predicción probabilística es la más completa e informativa. Para tener una predicción de este tipo hay que usar *ensembles* de modelos, que tratan de estimar la incertidumbre en el conocimiento del estado de la atmósfera y en su evolución. Hasta ahora esto existía para la predicción a medio plazo (desde los años 90), pero con el cambio de siglo, y ahora ya concretamente con el γ SREPS, es posible hacer predicción probabilística para el corto plazo.

El γ SREPS tiene el ambicioso objetivo de consolidarse como el estándar de la predicción operativa en AEMET para el corto plazo. Ahora mismo, el γ SREPS es un sistema de predicción meteorológica que no solo ofrece resultados de gran calidad, como se ha visto en el breve esbozo sobre verificación antes presentado, sino que es también un sistema tremendamente potente y único a nivel mundial. Ningún otro *ensemble* de corto plazo, hoy por hoy, tiene tantos modelos y condiciones de contorno como el γ SREPS. Por supuesto, esto conlleva un trabajo de mantenimiento importante, sobre todo a nivel de código y de adaptación de los diferentes modelos globales al formato del γ SREPS, además del trabajo científico explorando nuevas opciones que puedan implementarse.

6. AGRADECIMIENTOS

El redactor de este artículo quiere expresar su agradecimiento a todo el grupo de predictibilidad: de forma especial a su líder, Alfons Callado Pallarès, así como a Pau Escribà Ayerbe, David Gil Oliva y Mauri Martínez Sánchez. También a François Bouttier por la verificación conjunta con el AROME-EPS.

7. REFERENCIAS

- GARCÍA-MOYA, J. A. y otros, 2011. Predictability of short-range forecasting: a multimodel approach. *Tellus A*, vol. 63, no. 3, pp. 550-563. doi:10.1111/j.1600-0870.2010.00506.x.
- KALNAY, E. y HOU, D., 2001. Objective Verification of the SAMEX '98 Ensemble Forecasts, *Monthly Weather Review*, vol. 129, no. 1, pp. 73-91.
- PALMER, T. y HAGEDORN, R., 2014. Predictability of Weather and Climate. Cambridge University Press.
- PALMER, T. N. y otros, 2004. Development of a European multimodel ensemble system for seasonal-to-interannual prediction (DEMETER). *Bulletin of the American Meteorological Society*, 85(6), 853-872.
- SANTOS, C. y otros, 2018. Física del caos en la predicción meteorológica; (capítulo 21). Ministerio para la Transición Ecológica, Agencia Estatal de Meteorología. doi: 10.31978/014-18-009-x.